


VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH
TECHNOLOGIÍ
ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF BIOMEDICAL ENGINEERING

SEGMENTACE EEG SIGNÁLŮ

THE EEG SEGMENTATION

BAKALÁŘSKÁ PRÁCE
BACHELOR'S THESIS

AUTOR PRÁCE
AUTHOR

Anežka Nečadová

VEDOUCÍ PRÁCE
SUPERVISOR

Ing. Vladimíra Kubicová

BRNO, 2012



VYSOKÉ UČENÍ
TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

Ústav radioelektroniky

Bakalářská práce

bakalářský studijní obor
Elektronika a sdělovací technika

Studentka: Anežka Nečadová

ID: 128130

Ročník: 3

Akademický rok: 2011/2012

NÁZEV TÉMATU:

Segmentace EEG signálů

POKYNY PRO VYPRACOVÁNÍ:

Seznamte se s vlastnostmi, možnostmi snímání a zpracování EEG. Vytvořte rešerši o algoritmech segmentace EEG signálu, které rozdělí EEG signál na stacionární úseky. V programovém prostředí Matlab realizujte dva vybrané algoritmy segmentace. Funkčnost algoritmů ověřte na reálných EEG signálech a výsledky segmentace obou algoritmů porovnejte.

DOPORUČENÁ LITERATURA:

[1] MOHYLOVÁ, J. Zpracování signálu v lékařství. Elektronické skriptum. Žilina: Elektrotechnická fakulta, Žilinská univerzita, 2004.

[2] JAN, J. Číslíková filtrace, analýza a restaurace signálů. Brno: Nakladatelství VUTUM, 2002.

Termín zadání: 6.2.2012

Termín odevzdání: 25.5.2012

Vedoucí práce: Ing. Vladimíra Kubicová

Konzultanti bakalářské práce:

prof. Dr. Ing. Zbyněk Raida
Předseda oborové rady

UPOZORNĚNÍ:

Autor bakalářské práce nesmí při vytváření bakalářské práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

ABSTRAKT

Předmětem této bakalářské práce je seznámení se signálem EEG. Jsou zde rozebrány jeho vlastnosti, použití a způsoby zpracování. Hlavní část se zabývá segmentací EEG signálu. Dvě metody segmentace jsou realizovány v programu Matlab, a to adaptivní segmentace na základě míry difference střední amplitudy a míry difference střední frekvence a adaptivní segmentace na základě míry difference odhadnuté z rychlé Fourierovy transformace. Funkčnost algoritmu je ověřena na reálných EEG signálech.

KLÍČOVÁ SLOVA

Elektroencefalografie (EEG), segmentace signálu, Matlab

ABSTRACT

Subject of this bachelor project is the introduction of the EEG signal. Are discussed his characteristics, application and methods of processing. The main part deals with the segmentation of the EEG signal. Two methods are implemented in program Matlab - adaptive segmentation based on differential average amplitude and differential average frequency and adaptive segmentation based on differential estimated based on FFT. Functionality of algorithms is verified on real EEG signals.

KEYWORDS

Electroencephalography (EEG), signal segmentation, Matlab

NEČADOVÁ, A. *Segmentace EEG signálů*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií. Ústav biomedicínského inženýrství, 2012. 29 s., 7 s. příloh. Bakalářská práce. Vedoucí práce: ing. Vladimíra Kubicová.

Prohlášení

Prohlašuji, že svou bakalářskou práci na téma Segmentace EEG signálů jsem vypracovala samostatně pod vedením vedoucí bakalářské práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené bakalářské práce dále prohlašuji, že v souvislosti s vytvořením této bakalářské práce jsem neporušila autorská práva třetích osob, zejména jsem nezasáhla nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědoma následků porušení ustanovení § 11 a následujících zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

V Brně dne 25. května 2012

.....
podpis autora

Poděkování

Děkuji vedoucí bakalářské práce Ing. Vladimíře Kubicové za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé bakalářské práce.

V Brně dne 25. května 2012

.....
podpis autora

Seznam

Seznam	vi
Obsah obrázků	vii
Úvod	1
1. Elektroencefalografie	2
1.1 Snímání EEG signálu	2
1.1.1 Elektrody	2
1.1.2 Elektroencefalograf	5
1.1.3 Metodika snímání signálu	5
1.2 Artefakty	6
1.3 Normální EEG	7
1.3.1 Frekvence	7
1.3.2 Amplituda	8
1.3.3 Rozdělení EEG signálu	8
2. Segmentace signálu	11
2.1 Konstantní segmentace	11
2.2 Adaptivní segmentace – detekce nestacionarit	11
2.2.1 Adaptivní segmentace na základě lineární predikce	11
2.2.2 Adaptivní segmentace na základě autokorelační funkce	12
2.2.3 Adaptivní segmentace na základě míry difference odhadnuté z FFT	14
2.2.4 Adaptivní segmentace na základě míry difference střední amplitudy a frekvence	14
3. Programová realizace	16
3.1 Segmentace na základě difference střední amplitudy a frekvence	16
3.2 Segmentace na základě difference odhadnuté z FFT	21
3.3 Srovnání	23
Závěr	27
Použitá literatura	28
Seznam použitých zkratk	29
Přílohy	30

Obsah obrázků

Obr. 1: Rozložení elektrod [7].....	3
Obr. 2: Bipolární režim [6].....	4
Obr. 3: Unipolární režim [6]	4
Obr. 4: Zprůměrněný režim [6]	4
Obr. 5: Originální signál [6]	9
Obr. 6: Alfa vlny [6].....	9
Obr. 7: Beta vlny [6]	9
Obr. 8: Theta vlny [6].....	9
Obr. 9: Delta vlny [6]	9
Obr. 10: Gamma vlny [6]	10
Obr. 11: Adaptivní segmentace na základě lineární predikce [3]	12
Obr. 12: Adaptivní segmentace na základě autokorelační funkce [3].....	13
Obr. 13: Princip metody adaptivní segmentace se spojenými okny [3]	15
Obr. 14: Aplikace segmentační metody na Gaussovském šumu	17
Obr. 15: Aplikace segmentační metody na Gaussovském šumu – nízké hodnoty difference ...	17
Obr. 16: Aplikace segmentační metody na Gaussovském šumu – překročení meze	17
Obr. 17: Aplikace segmentační metody na Gaussovském šumu – malá délka okna	18
Obr. 18: Aplikace segmentační metody na Gaussovském šumu – velká délka okna	18
Obr. 19: EEG signál	19
Obr. 20: Algoritmus segmentace kanálu 1	19
Obr. 21: Algoritmus segmentace kanálu 2	20
Obr. 22: Algoritmus segmentace kanálu 3	20
Obr. 23: Aplikace druhé segmentační metody na Gaussovském šumu	21
Obr. 24: Nalezené hranice segmentu s použitím meze nalezené pomocí bílého šumu.....	22
Obr. 25: Algoritmus druhé segmentace kanálu 1	22
Obr. 26: Algoritmus druhé segmentace kanálu 2	23
Obr. 27: Algoritmus druhé segmentace kanálu 3	23
Obr. 28: Srovnání výsledků segmentačních metod pro kanál 1	24
Obr. 29: Srovnání výsledků segmentačních metod pro kanál 2	24
Obr. 30: Srovnání výsledků segmentačních metod pro kanál 3	25
Obr. 31: Závislost délky výpočtu na délce EEG záznamu	26

Úvod

Lidský mozek je nejsložitější a tím snad i nejzajímavější orgán lidského těla. Jeho činnost nikdy během našeho života neustane. Stále jsou v mozku přenášeny informace elektrickými impulzy s rychlostí až stovek kilometrů za hodinu a to i když spíme i při nejhlubším komatu. I přes pokročilou vědu je nám mnohé z oblasti elektroencefalografie tajemstvím. Tato práce shrnuje jen obecné poznatky o mozkových impulzech, o jejich získávání a vyhodnocování.

V první kapitole je probrán teoretický úvod do elektroencefalografie. Popisuje základní vlastnosti EEG signálu a problematiku jeho zpracování.

Druhá kapitola je věnována popisu metod pro segmentaci EEG signálů, což je důležitá část předzpracování EEG signálu.

V poslední části práce je uvedený popis programového řešení dvou vybraných metod segmentace – segmentace stanovená na základě difference odhadnuté ze střední amplitudy a difference střední frekvence a segmentace na základě míry difference odhadnuté z FFT. Následně jsou rozebrány výsledky segmentace a vlastnosti obou metod při aplikaci na reálných EEG záznamech. Na závěr jsou tyto dvě metody porovnány.

1. Elektroencefalografie

Elektroencefalografie je diagnostická metoda, kterou se zaznamenává elektrická aktivita mozku. Základní součástí nervové soustavy tedy i mozku je neuron. Tato nervová buňka je elektricky excitabilní (vzrušivá) buňka, která je schopna reagovat na podměty změnou elektrických vlastností své membrány. V mozku dochází k neustálým změnám polarizace neuronů, ty se zaznamenávají do elektroencefalogramu.

EEG nachází hlavní využití při diagnostice poruch spánku a epilepsie. Epilepsie je záchvatovitěho onemocnění mozku projevující se záchvaty křečí a dalšími poruchami. Diagnostika na základě abnormálních vzorců v EEG tzv. epileptiformní vzorce-zejména tzv. hroty nebo komplexy hrot-vlna v určité oblasti nebo celého mozku. Podle elektrické aktivity mozku ve spánku se rozlišují jednotlivá spánková stadia a případné poruchy spánku. Pomocnou roli má EEG při určení hloubky poruchy vědomí (komatu apod.), účinku farmak, diagnostice bolestí hlavy (zejména migrény), poranění mozku a stanovení mozkové smrti. Biofeedback neboli EEG biologická zpětná vazba je zařízení pro trénování mozku. Slouží k navozování definovaných stavů například relaxace nebo zvýšení výkonu.

První zmínka o produkci elektrických fenoménů živou tkání pochází z druhé poloviny 18. století od Luigi de Galvaniho a A. Volty. V polovině 19. století Du Bois Raymond vyvinul nepolarizovanou elektrodu, kterou registroval elektrickou aktivitu žabího mozku. 1875 Richard Caton popsal elektrické proudy králíčích a opičích mozků. 1890 Adolf Beck zaznamenal pravidelné elektrické průběhy v různých oblastech mozkové kůry (cerebral cortex). Elektrická aktivita lidského mozku byla poprvé registrována Hansem Bergerem v roce 1924. V roce 1934 pak Adrian rozšířil znalosti o mozkových rytmech a zpřesnil charakteristiku alfa aktivity. V 30. letech 20. století firmy Drahoocki, Walter, Kaiser, Toennies sestrojily jednoúčelové zařízení k registraci elektrické mozkové aktivity.

1.1 Snímání EEG signálu

Snímá se signál vzniklý superpozicí celé řady jednodušších signálů. Záznam, který získáme, se nazývá elektroencefalogram (EEG).

1.1.1 Elektrody

Chceme-li současně sledovat elektrickou aktivitu v různých částech, musíme na povrch kůže hlavy umístit celou řadu elektrod. Elektrody jsou prvním elementem, který zajišťuje převod elektrické aktivity z mozku do zesilovačů EEG přístroje.


Elektrickou charakteristiku elektrod udává druh použitého kovu a tekuté medium, které společně v klidovém stavu vytvářejí elektrický potenciál a při průchodu proudem dochází k polarizaci. Pro snímání EEG se využívají elektrody z kovu, který je nepolarizovaný a umožňuje přenos rychlých změn. Nejčastěji se používají elektrody ze stříbra potažené tenkou vrstvičkou chloridu stříbrného a roztok chloridu stříbrného, některé speciální jsou z nerezových ocelí nebo speciálních slitin.

Podle umístění elektrod rozlišujeme elektrody povrchové a jehlové elektrody podkožní. Dále se používají speciální elektrody nasofaryngeální, tympanální, sfenoidální, kortikální.

Povrchové elektrody jsou většinou kruhovitěho tvaru o průměru 7 - 10 mm. Jejich rozměr nesmí být velký, aby bylo přesně definováno místo snímání. Umisťují se pod masku z gumových proužků. Dále se používají elektrodové čepice zhotovené z pružné tkaniny, na které jsou umístěny speciální miskovité elektrody.

Snímání přímo z povrchu mozkové kůry pomocí podpovrchových elektrod je invazivní metoda, která se používá méně často. Reprezentace elektrické aktivity získaná touto metodou se nazývá elektrokortikogram.


Elektrody jsou rozmístěny podle systému 10-20 (obr. 1). Vychází ze čtyř bodů: nasion (kořen nosu), inion (výstupek na týlní kosti), bodu před ušním boltcem vpravo a vlevo. Vzdálenost mezi dvěma z těchto bodů v podélném či příčném směru je rozdělena tak, aby elektrody byly vzdáleny 10, 20, 20, 20, 10 procent celkové distance. Tyto relativní vzdálenosti jsou pak platné jak v podélném tak transversálním směru.




Obr. 1: Rozložení elektrod [7]

Na vstup zesilovače každého kanálu jsou připojeny vždy dva póly a to buď od dvou elektrod, nebo jedné elektrody a referenčního bodu. Což je definováno jako zapojení bipolární (obr. 2) a unipolární (obr. 3).


Třetí možností je zapojení se společnou referenční elektrodou neboli zprůměrněné zapojení (obr. 4). Zde jsou všechny elektrody připojeny přes odpor, stejný pro všechny elektrody, k jedinému bodu, který tvoří jeden pól, a na druhý pól vstupu jsou připojeny jednotlivé elektrody [2].



Obr. 2: Bipolární režim [6]



Obr. 3: Unipolární režim [6]



Obr. 4: Zprůměrněný režim [6]

1.1.2 Elektroencefalograf

Pomocí předzesilovače se zesílí signál mikrovlnné úrovně na milivoltovou, tedy asi 1000 krát. Jeho vstupní odpor má být co největší na úrovni megaohmů. Je využíván tzv. diferenční zesilovač [1].

Hlavní zesilovač opět zesílí předzesílený signál asi 1000 krát. Potlačuje soufázový signál (CMR [dB]). Musí být zajištěna co největší synchronizace kanálů a odstranění souhlasných signálů [1].

Ze vstupního signálu převedeme k registraci jen frekvenční pásmo, které nás zajímá, klasicky 0,5 až 70 Hz. To získáme pomocí horního a dolního filtru. Navíc je filtrována rušivá síťová frekvence 50 Hz [1].

K registraci EEG signálu můžeme použít některé z řady mechanismů.

Jedna z možností je použít přímo písíci pero. Jeho výhodou je stabilita vlastností, dlouhá životnost, levný inkoust, možnost použití normálního papíru. Naproti tomu nevýhodou je vysychání inkoustu, zkreslení záznamu [1].

Kopírování přes kopírovací pásku nebo kopírovací papír má za výhodu přesné vykreslení hrotů, ale nevýhodou je závislost kvality zápisu na kvalitě přitlačeného bříty písátka a manipulace s papírem či páskou [1].

Tryskový systém je způsob sice přesnější, ale může docházet k ucpání trysky. Další nevýhodou je vysoká cena [1].

Magnetický záznam na magnetofonovou pásku se využívá především pro dlouhodobé sledování EEG (long time EEG) [1].

Magnetický záznam na počítačová paměťová media je tzv. bezpapírové EEG. Největšími výhodami tohoto způsobu je zachování surových dat ze všech elektrod, možnost je jakkoli dále zpracovávat a porovnávat, rovněž také úspora archivovacího prostoru [1].

1.1.3 Metodika snímání signálu

EEG přístroj by měl být umístěn v elektricky a akusticky stíněné místnosti. Pacient by měl přijít na vyšetření s umytou hlavou bez tužidel, masť apod. Trvání záznamu musí být nejméně dvacet minut. Nutné je natočení záznamu v referenčním, longitudinálním a transversálním zapojení [1].

Na počátku a na konci grafu je fyzikální kalibrace a biologický test. Kalibrace spočívá v připojení všech paralelně spojených vstupů zesilovače k jednomu zdroji kalibračního napětí. To je obvykle generátor obdélníkových impulsů nebo napěťový skok.

Další možnost kalibrace je připojení jednotlivých vstupů zesilovače k několika zdrojům kalibračního napětí. To je celkem složité; lze provádět kontrolu citlivosti i v průběhu snímání.

Biologický test spočívá v tom, že všechny elektrody se spojí a přivede se na ně biologický signál přímo z pacienta. Pokud mají všechny kanály přístroje stejné vlastnosti, měl by být ve všech kanálech stejný záznam.

V každém grafu v každém zapojení je zkoušena reaktivita – AAR alfa atenuační reakce. RF remund fenomén, u pacientů v bezvědomí pasivně a navíc reakce na zvuk a na bolest. V běžném záznamu by měla být hyperventilace nosem 2 minuty, hyperventilace ústy 4 minuty, fotostimulace záblesky většinou vzestupnou a sestupnou řadou po 1 až 5Hz do 30Hz, výjimečně randomizačně.

Hyperventilace je aktivační metoda, kterou docílíme většího výdeje kyslíčnicku uhličitého z organismu, dojde k poklesu jeho hladiny v krvi, k zúžení mozkových cév a tedy i snížení zásobení mozkových buněk živinami, hlavně kyslíkem. Tato změna způsobí, že v některých případech dochází k manifestaci latentních abnormit v EEG [2].

Fotostimulace se provádí mihotavým světlem reflektorem vzdáleným deset až dvacet centimetrů od zavřených očí. Záblesky jsou velmi krátkého trvání o intenzitě 0,1 až 0,6 joulů. Nejdříve se aplikují jednotlivé záblesky, pak pravidelné frekvence různě odstupňované. Jeden z postupů je, že se kmitočty v rozsahu 1 – 20 Hz mění vždy o 1 Hz, přičemž každou frekvencí se stimuluje asi deset vteřin. Objeví-li se však abnormity pak se touto frekvencí pokračuje [2].

Kromě klasického vyšetření EEG se používá Holterovo monitorování tzv. long time EEG. Toto dlouhodobé monitorování trvá 24 a více hodin. V praxi je využíváno zejména u stavů porušeného vědomí [1].

Pro výzkum spánku, pro určení jednotlivých spánkových stádií se zavedlo celonoční snímání EEG.

Video EEG je kombinací klasického EEG a video zařízení. Na jedné části obrazovky je zobrazován signál přivedený z klasického EEG přístroje v obvyklé podobě a na druhé straně obrazovky je snímán pacient (na lůžku JIP, přímo v EEG laboratoři). Zařízení jsou synchronizována, takže výsledkem je současný obraz pacienta a jeho mozková aktivita [1].

Technicky jsou pro automatické zpracování signálu dva základní konstrukční přístupy. Programy přímo zabudované v hardware a systém, kdy celý zpracovatelský program je na paměťových médiích jak software, což je výhodnější vzhledem k tomu, že je možno jej inovovat či upravovat dle požadavků [1].

Analogový signál snímáný elektrodami z povrchu lbi je digitalizován a dále zpracováván různými matematickými metodami, z nichž je nejčastěji využívána pro spektrální analýzu rychlá Fourierova transformace (FFT), méně intervalová analýza a pro vyhledávání přesně definovaných tvarů rozpoznávací metoda (například SW komplexy) atd. [1].

1.2 Artefakty

Artefakty rozumíme zkreslení EEG křivky elektrickými potenciály, které nemají původ v centrálním nervovém systému. Původ těchto signálů může být dvojího typu a to technický a biologický.

Do technických artefaktů se řadí tzv. artefakt 50Hz. Je to způsobeno tím, že se do záznamu dostávají potenciály ve frekvenci střídavého proudu.

Elektrodové artefakty mohou být způsobeny nějakou poruchou elektrody. Jsou to pomalé vlny vyššího napětí, často obdélníkového tvaru.

Přístrojové artefakty mohou být způsobeny například vadnou elektronkou vstupního zesilovače, znečištěním kontaktu kabelu elektrody, poruchou zapisovacího galvanometru, zapínáním a vypínáním přístrojů nebo změny hodnot filtrů při registraci aj.

Mezi biologické artefakty patří svalový potenciál, který se projevuje jako velmi rychlá nepravidelná aktivita s ojedinělými, izolovaně nebo ve skupinách se objevujícími ostrými hroty.

Dalším biologickým artefaktem u EEG je artefakt EKG. Může se projevit při snímání signálu z uší. Pravidelnost těchto artefaktů umožňuje snadnou diferenciaci od hrotových potenciálů mozkového původu.

V EEG záznamu se může objevit artefakty pulzové vlny. Jsou to pomalé vlnky nižší amplitudy synchronně s tepem, způsobené pohybem elektrody. Odstranění artefaktu se provede posunutím elektrody mimo cévu.

Biologický artefakt způsobený pohybem očí se projevuje jako pomalé vlny arkádového tvaru, případně pilovitého, rytmicky nad předními kvadranty.

Další biologické artefakty mohou být způsobeny pocením, dýcháním, polykáním, dále kožní potenciály aj.

1.3 Normální EEG

EEG obsahuje široké frekvenční spektrum, rytmicita utváří určité zákonitosti v amplitudách i frekvencích. Rytmicita není znakem normality, stejně patří k abnormalitě. V podstatě neexistuje přesné rozhraní mezi abnormálním a normálním EEG. Na základě rozsáhlých studií byla stanovena kritéria normality. Byla snaha o stanovení normy pro jednotlivé věkové skupiny, bdělost, spánek apod. Tyto tzv. normy je však nutno považovat za orientační [1].

1.3.1 Frekvence

Za klinicky využitelné pásmo je považováno rozmezí 0.1 Hz až 100 Hz a ve více vyhraněné podobě 0.5 až 70 Hz. Tyto frekvence jsou děleny do několika pásem: delta - 0.1 až 4 Hz, theta - 4 až 8 Hz, alfa - 8 až 13 Hz, beta - nad 13 Hz, obvykle 13 až 30 Hz, gamma – nad 30 Hz. Pojmenování pásem není logické, ale je historické.

Z hlediska frekvence, může být EEG aktivita rytmická (sled vln více méně konstantní frekvence), arytmičká (bez žádného pravidelného rytmu), dysrytmická (nepravidelná směs různých frekvencí) [1].

1.3.2 Amplituda

Napětí EEG záznamu je determinováno amplitudou signálu původního. Ta je ovlivněna průchodem přes jednotlivé vrstvy obalu mozku, které signál výrazně zmenšují a mění. EEG amplituda je měřena mezi vrcholy sousední negativy a pozitivy. V praxi není nutné přesné měření, stačí zhodnocení nízká, střední nebo vysoká [1].

1.3.3 Rozdělení EEG signálu

Alfa aktivita

Aktivita o frekvenci 8 až 13 Hz, která se objevuje během bdělosti nad zadními oblastmi hlavy, všeobecně vyšší napětí nad occipitální (týlní) oblastí, proměnlivé amplitudy, obvykle do 50 μ V. Nejlépe je viditelná při zavřených očích, fyzické relaxaci a při relativní mentální aktivitě. Blokována nebo atenuována je pozorností, zvláště zrakovou nebo mentální (obr. 6) [1].

Beta aktivita

Jedná se o aktivitu nad 13 Hz bez jasnějšího omezení k rychlejším frekvencím, nacházející se zejména nad předními a středními částmi lbi. Centrální beta je blokována pohybem. Beta aktivita je rozdělena na frontální 25 až 30 Hz, objevující se v krátkých úsecích a 20 až 25 Hz větší amplitudy v nepravidelných periodách. Relativně více se beta vyskytuje u žen, než u mužů (obr. 7) [1].

Theta aktivita


Aktivita o frekvenci 4 až 8 Hz hraje významnou roli ve vyzrávání EEG. Podle zastoupení theta lze tvrdit, že EEG je vyzrálý ve 25 až 30 letech. Theta aktivita je generována samostatně od alfa rytmu (obr. 8) [1].

Delta aktivita


Aktivita o frekvenci 0.5 až 4 Hz je označována jako delta aktivita. V bdělém stavu je u dospělých patologií, společně s theta aktivitou má význam v hodnocení vývoje elektroencefalogramu a při určování spánkových stádií (obr. 9) [1].

Gamma vlny


Aktivita o frekvenci 22 –30 Hz a více. Můžeme ji pozorovat při vysoké pozornosti. Docílíme jí senzorickou stimulací (obr. 10).




Obr. 5: Originální signál [6]




Obr. 6: Alfa vlny [6]




Obr. 7: Beta vlny [6]



Obr. 8: Theta vlny [6]



Obr. 9: Delta vlny [6]



Obr. 10: Gamma vlny [6]

2. Segmentace signálu

Segmentací signálu rozumíme rozdělení signálu na menší části. Provádí se za účelem dalšího zpracování signálu a případného odstranění nežádoucích artefaktů.

Rozpoznáváme dva typy segmentace:

1. konstantní segmentace – konstantní délka segmentu
2. adaptivní segmentace – proměnná délka segmentu

2.1 Konstantní segmentace

Konstantní segmentace spočívá v tom, že délka okna má stále stejnou délku, obsahuje stejný počet vzorků. Nevýhodou tohoto rozdělení je, že hranice úseků nemají žádný vztah k charakteru signálu. Za výhodu můžeme považovat jednoduchost implementace algoritmu na rozdělení.

2.2 Adaptivní segmentace – detekce nestacionarit

Biologické signály nemají stacionární charakter, což znamená, že jejich frekvenční i amplitudové vlastnosti se s časem mění. V signálu se mohou vyskytnout různé artefakty, případně nestacionarity (transienty), jako jsou například u EEG aktivity epileptické grafoelementy a podobně. Pro spektrální analýzu je řešením rozdělit signál do po částech stacionárních úseků proměnné délky v závislosti na výskytu nestacionarit v signálu [3].

2.2.1 Adaptivní segmentace na základě lineární predikce

Metoda vychází z autoregresního (AR) modelu signálu

$$x_n = -\sum_{k=1}^p a_k x_{n-k} + e_n \quad (2.1)$$

kde koeficienty a_0, a_1, \dots, a_p reprezentují lineárně predikční (LP, Wienerův) filtr. Filtr transformuje vstupní posloupnost do posloupnosti nekorelovaných náhodných veličin. e_n se nazývá chyba predikce a představuje chybu, které se dopouštíme při odhadu hodnoty x_n z lineární kombinace p minulých vzorků signálu.

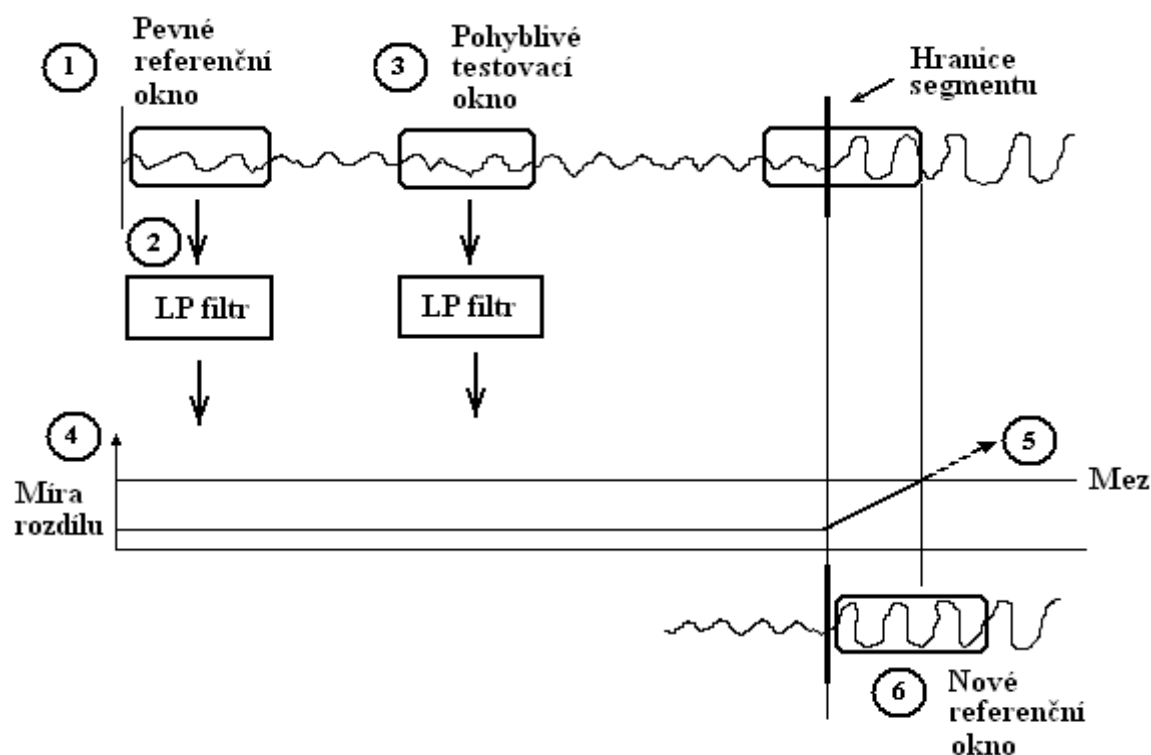
Princip:

1. Na začátku každého segmentu se umístí krátké (1 sec) pevné referenční okno.
2. V tomto okně se odhadnou charakteristiky signálu – koeficienty LP filtru – tento filtru se adaptuje na signál.
3. Signál se nechá procházet filtrem inverzním k odhadnutému filtru a sleduje se jeho výstup - chyba predikce. Pokud je filtr adaptován na signál (signál je stacionární),

bude chyba predikce nekorelovaná (její autokorelační funkce bude nulová) a spektrum e_n se nebude lišit od spektra bílého šumu. Objeví-li se nová spektrální složka, LP filtr přestává být adaptován na signál.

4. Z autokorelační funkce chyby predikce vyplývající z průchodu EEG daným filtrem se určí míra difference mezi spektry signálu v referenční a testovací oblasti.
5. Signál se považuje za kvazi-stacionární, nepřekročí-li míra rozdílu testovací a referenční oblasti stanovenou mez. V opačném případě se indikuje hranice segmentu uprostřed testovacího okna.
6. LP filtr (nové referenční okno) se adaptuje (umístí) na nový segment a postup se opakuje.

Princip metody vycházející z lineární predikce [3].



Obr. 11: Adaptivní segmentace na základě lineární predikce [3]

2.2.2 Adaptivní segmentace na základě autokorelační funkce

Předchozí metoda sice vychází z teorie lineární predikce, ale pro určení míry spektrální odchylky se používá autokorelační funkce chyby predikce generované LP filtrem, jehož koeficienty se počítají z autokorelační funkce signálu.

Princip:

1. Na začátku segmentu se umístí pevné referenční okno. V tomto okně se určí charakteristiky signálu.

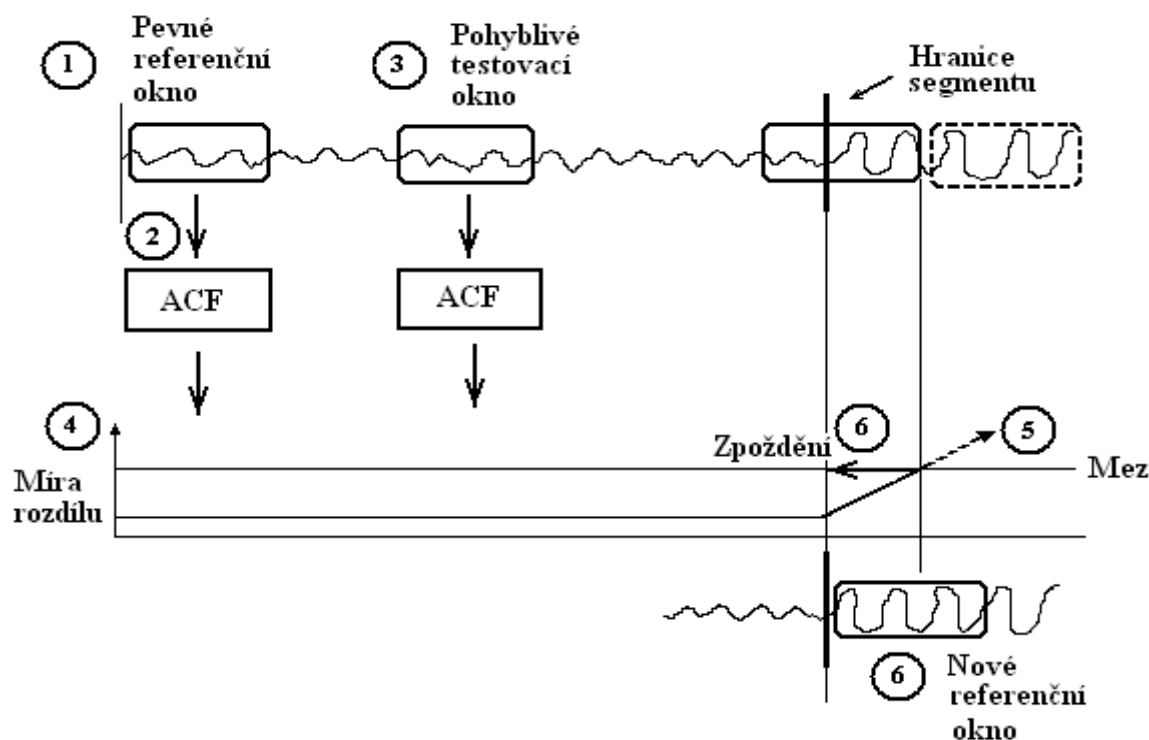
- Po signálu klouže druhé pohyblivé testovací okno a v tomto testovacím okně se průběžně počítají charakteristiky signálu.
- Z rozdílu charakteru signálu v obou oknech se určí míra difference (odchylka od stacionarity).
- Jakmile míra difference překročí pevnou, předem stanovenou mez, je indikována změna stacionarity signálu (hranice segmentu).
- Její přesná poloha se odhadne z dalšího průběhu signálu.
- Nové referenční okno se umístí opět na začátek nového segmentu a procedura se opakuje. Míra difference se počítá z rozdílu autokorelačních funkcí referenčního a testovacího okna:

$$DIFF = \sum_{n=0}^{ACFL} \frac{|R_{W1}(n) - R_{W2}(n)|}{R_{W1}(0)R_{W2}(0)} \quad (2.2)$$

kde R_W je autokorelační funkce okna, $W1$, $W2$ jsou dvě oddělená okna (referenční a testovací) a $ACFL$ je počet koeficientů autokorelační funkce.

Zpoždění okamžiku indikace změny stacionarity za skutečnou hranicí segmentu se odhadne z dalšího průběhu signálu – pohybujeme oknem ještě do vzdálenosti délky okna od indikované změny a předpokládáme, že sklon míry zpoždění je úměrný poměru obou oken.

Tato metoda má jednu podstatnou nevýhodu, a to že není vhodná pro nezávislou segmentaci vícekanálového záznamu současně, což vylučuje on-line vícekanálovou segmentaci v reálném čase. Důvodem je ztráta synchronizace pohybu oken při umístění nového referenčního okna na začátek nového segmentu. Řešení tohoto problému přinesla metoda využívající pro detekci změny stacionarity dvou spojených oken, které se pohybují po signálu současně [3].



Obr. 12: Adaptivní segmentace na základě autokorelační funkce [3]

2.2.3 Adaptivní segmentace na základě míry difference odhadnuté z FFT

Metoda adaptivní segmentace je založena na základě míry difference, jenž je odhadnutá z rychlé Fourierovy transformace (FFT).

Princip:

1. Po signálu kloužou dvě spojená okna.
2. Z rozdílu charakteru signálu v obou oknech se určí míra difference (odchylka od stationarity).
3. Hranice segmentu je umístěna v místech lokálních maxim míry difference. Vliv nevýznamných fluktuací míry difference je omezen minimální mezí pro segmentaci.

Problém této metody spočívá v tom, že jako míru difference autoři používají rozdíl spektrálních obsahů oken, počítaných pro každý posun oken z rychlé Fourierovy transformace (FFT) :

$$DIFF = \max_{\omega} \left\{ \frac{1}{2} \left[\frac{X_t(\omega)}{Y_t(\omega)} + \frac{Y_t(\omega)}{X_t(\omega)} \right] - 1 \right\} \quad (2.3)$$

kde $X(t)$ a $Y(t)$ označuje spektrální obsah dvou spojených oken (určený na základě FFT).

Metoda je proto velmi pomalá (musíme počítat FFT pro každý posun oken) a hlavně nespolehlivá, produkuje falešná lokální maxima v sousedství skutečných hranic segmentů. Odhady spektra je navíc nutné vyhlazovat oknem [3].

2.2.4 Adaptivní segmentace na základě míry difference střední amplitudy a frekvence

V této metodě je míra difference odhadnutá ze střední amplitudy a frekvence.


Tento algoritmus využívá pro stanovení míry difference velmi jednoduchých (a tím i rychlých) odhadů amplitudové a frekvenční míry difference, založených na odhadu střední amplitudy A_W a střední frekvence F_W v příslušných spojených oknech $W1$, $W2$ (délka okna je WL) :

$$A_W = \sum_{i=1}^{WL} |x_i| \quad (2.4)$$

$$F_W = \sum_{i=1}^{WL} |x_i - x_{i-1}| \quad (2.5)$$

Metoda vychází z poznatku, že průměrná difference vzorků signálu je přímo úměrná střední frekvenci signálu v daném okně. Míra difference oken je pak vytvořena kombinací obou částí, po vynásobení váhovými koeficienty získanými experimentálně (váha pro míru frekvenční difference je sedmkrát větší než váha pro amplitudový odhad).

Tento postup umožňuje v principu on-line zpracovávání vícekanálových signálů, přičemž segmentace postupuje v každém kanálu nezávisle na ostatních kanálech [3].



Obr. 13: Princip metody adaptivní segmentace se spojenými okny [3]

3. Programová realizace

V programu Matlab byly realizovány dvě metody adaptivní segmentace:

1. Segmentace stanovená na základě difference odhadnuté ze střední amplitudy a difference střední frekvence.
2. Segmentace stanovená na základě míry difference odhadnuté z FFT.

3.1 Segmentace na základě difference střední amplitudy a frekvence

Zdrojový kód programu je uveden v příloze.

Po načtení EEG záznamu se nechá po signálu klouzat dvě spojená okna. Obě okna mají stejnou délku.

Pro každé okno se vypočítá střední amplituda (2.4) a střední frekvence (2.5). Z těchto hodnot je pak následně vypočítána míra difference oken podle vztahu:


$$G = k_A |A_{W1} - A_{W2}| + k_F |F_{W1} - F_{W2}| \quad (3.1)$$

kde k_A a k_F jsou váhové koeficienty. Jelikož váha pro míru frekvenční difference se většinou udává sedmkrát větší než váha pro amplitudový odhad, byly zvoleny hodnoty $k_A = 1$ a $k_F = 7$.


Vyhodnocením průběhu míry difference G pro určitý kanál EEG záznamu se stanoví jednotlivé segmenty. Pokud průběh křivky G překročí stanovenou mez, hledá se lokální maximum. V místě lokálního maxima se označí hranice segmentu.

Hodnota délky okna a výše meze pro diferenci se stanoví pomocí bílého šumu. Bílý šum je stacionární ryze náhodný proces, který má nulovou střední hodnotu a konstantní spektrální výkonovou hustotu. Reálně však tyto vlastnosti nemohou existovat, neboť hodnoty bílého šumu v libovolně vzdálených časových okamžicích jsou nekorelované a středně kvadratická hodnota je nekonečná. V praxi se tedy generuje aditivní šum s normálním rozložením (AWGN - Additive white Gaussian noise) bílým šumem.


V programu Matlab byl vygenerován bílý šum o podobných vlastnostech jako má EEG signál. A na tomto průběhu se aplikoval vytvořený algoritmus segmentace. Jelikož bílý šum je v základu stacionární, průběh difference by stanovenou mez neměl překročit. Příklad průběhu difference můžeme vidět na obr. 14, z něhož byla odvozena hranice pro segmentaci 2800. Po opětovném generování šumu se několikrát difference k stanovené mezi přiblížila jen vzdáleně (obr. 15). Výjimečně došlo i k překročení této meze (obr. 16).



Obr. 14: Aplikace segmentační metody na Gaussovském šumu




Obr. 15: Aplikace segmentační metody na Gaussovském šumu – nízké hodnoty difference




Obr. 16: Aplikace segmentační metody na Gaussovském šumu – překročení meze

Délka okna byla stanovena tzv. zkusmo. Při malé délce okna byly hodnoty průběhu difference velmi malé (obr. 17). Se zvětšováním velikosti okna se zvyšovaly i hodnoty difference. Kolem hodnoty 50 vzorků na jedno okno se však tento růst zastavil a průběh difference již s navyšováním vzorků v okně výrazněji nevzrostl. S nastavením velké délky okna se navíc zkracoval průběh difference a tím i délka nesegmentovaného signálu (obr. 18). Bylo tedy zvoleno 60 vzorků na jedno okno.



Obr. 17: Aplikace segmentační metody na Gaussovském šumu – malá délka okna




Obr. 18: Aplikace segmentační metody na Gaussovském šumu – velká délka okna


Dalším bodem, který je potřeba vyřešit v programovém řešení této metody je nalezení lokálních maxim pro ohraničení segmentů. Zde byl zvolen následující postup: V prvním kroku se vzorkům nepřesahující stanovenou mez přiřadila nulová hodnota a vytvořil se vektor P, který obsahoval pozice nenulových vzorků. V místě, kde rozdíl dvou sousedních prvků vektoru P byl větší než jedna, neboli v místě, kde průběh difference protínal mez, se stanovily tzv. hranice. Mezi těmito hranicemi se hledalo lokální maximum v průběhu difference, na jehož pozici pak byla v průběhu EEG kanálu vyznačena hranice segmentu.

Výstupem programu pro vyhodnocení adaptivní segmentace je graf s průběhy zpracovávaného EEG signálu (obr. 19) a grafy vybraného kanálu. Příklady vyhodnocení


jednotlivých kanálů EEG jsou uvedeny na obrázcích 20 až 22. V prvním řádku je zobrazen časový průběh vybraného kanálu EEG signálu. Ve druhém řádku každého obrázku je pak průběh difference s vyznačením zvolené meze. Ve třetím řádku je viděn průběh signálu již s vyznačenými hranicemi segmentu pomocí vertikálních čar.




Obr. 19: EEG signál



Obr. 20: Algoritmus segmentace kanálu 1



Obr. 21: Algoritmus segmentace kanálu 2



Obr. 22: Algoritmus segmentace kanálu 3


3.2 Segmentace na základě difference odhadnuté z FFT

Jako druhý typ adaptivní segmentace byl zrealizován algoritmus, který vyhodnotí segmenty na základě míry difference odhadnuté z rychlé Fourierovy transformace. Metoda se zakládá na podobném principu jako předchozí způsob. Po signále se opět nechají klouzat dvě spojená okna. V každém kroku se vypočítá jejich spektrální obsah podle vzorce


$$X_n = \sum_{m=0}^{N-1} x_m e^{\frac{j2\pi kn}{N}} \quad (3.2)$$

a z těchto hodnot se pak získá difference (2.3).

I zde byla snaha stanovit mez pro diferenci na základě vlastností bílého šumu (obr. 23). Z obrázku je vidět, že difference nepřekročila hodnotu $G=200$. Po aplikaci zjištěné meze na reálném EEG signálu však program vyhodnotil příliš mnoho nalezených segmentů (obr. 24). Proto byla zvolena mez vyšší $G=6 \cdot 10^{12}$. Okno bylo použito o délce šedesáti vzorků signálu stejně jako v předchozí metodě segmentace.




Obr. 23: Aplikace druhé segmentační metody na Gaussovském šumu




Obr. 24: Nalezené hranice segmentu s použitím meze nalezené pomocí bílého šumu


Příklady vyhodnocení segmentace jednotlivých kanálů tímto algoritmem jsou na obrázcích 25 až 27.



Obr. 25: Algoritmus druhé segmentace kanálu 1



Obr. 26: Algoritmus druhé segmentace kanálu 2




Obr. 27: Algoritmus druhé segmentace kanálu 3


3.3 Srovnání

Pokud se podíváme na jednotlivé výstupy segmentačních metod, vidíme, že každý algoritmus


vyhodnotil rozdílné hranice segmentů (obr. 28 až obr. 30). V prvním uvedeném příkladu vidíme, že první metoda vyhodnotila pouze tři segmenty, zatímco druhá metoda segmentů osm. Jindy byl počet segmentů obou metod srovnatelný. Nalezené hranice byly však vždy v odlišných pozicích. Při volbě segmentace tedy musíme zvážit, za jakým účelem chceme signál rozdělit na menší úseky a jak s nimi budeme nadále pracovat.



Obr. 28: Srovnání výsledků segmentačních metod pro kanál 1




Obr. 29: Srovnání výsledků segmentačních metod pro kanál 2



Obr. 30: Srovnání výsledků segmentačních metod pro kanál 3

Další rozdíl mezi zmíněnými druhy segmentace je v rychlosti výpočtu. První metoda je početně jednoduchá a tedy i rychlá. Naproti tomu segmentace, kde pro každý posun oken počítáme jejich spektrální obsah pomocí FFT, je velice pomalá. Při zpracovávání zmíněného signálu, který má přibližně 8s, není časový rozdíl výpočtu jednotlivých metod tak zřetelný. Při aplikaci na delší signál dosahující dvaceti minut již však není doba výpočtu metody s FFT zanedbatelná.

Za účelem srovnání časové závislosti byl v programu Matlab zhotoven graf, který popisuje závislost doby výpočtu na délce signálu, tedy jak dlouho trvá výpočet pro různou délku EEG záznamu (obr. 31).



Obr. 31: Závislost délky výpočtu na délce EEG záznamu (**červeně** – metoda s výpočtem A_W a F_W , **modře** – metoda s výpočtem FFT)

Závěr

Cílem bakalářské práce bylo seznámit se s vlastnostmi a možnostmi zpracování EEG signálu, zvláště pak s možnostmi segmentace signálu. V programovém prostředí Matlab realizovat dva vybrané algoritmy segmentace a ověřit jejich funkčnost na reálných EEG signálech.

V prvních kapitole jsou popsány základní poznatky o elektroencefalografii a zpracování EEG signálu. Jsou zde zmíněny způsoby získávání a využití EEG záznamu, artefakty EEG křivky a vlastnosti normálního EEG. V druhé kapitole jsou podrobně rozebrány různé algoritmy pro segmentaci signálu.

Třetí kapitola popisuje programovou realizaci segmentačních metod. Jsou zde uvedeny příklady výsledků rozdělení reálného EEG signálu na stacionární úseky. Na závěr je srovnán algoritmus segmentace stanovené na základě difference odhadnuté ze střední amplitudy a difference střední frekvence s algoritmem segmentace stanovené na základě míry difference odhadnuté z FFT. Podle předpokladů je druhý způsob segmentace časově mnohem náročnější na výpočet než první způsob. Dále se předpokládalo, že obě segmentační metody vyhodnotí podobné hranice segmentů. Tento předpoklad se však nenaplnil. Každá metoda vyhodnotila hranice stacionárních úseků v rozdílných pozicích EEG signálu.

Použitá literatura

- [1] MORÁŇ, M. *Praktická elektroencefalografie*. 1. vydání, Brno: Institut pro další vzdělávání pracovníků ve zdravotnictví, 1995. ISBN 80-7013-203-5.
- [2] MIŠUREC, J; CHMELAR, M. *Elektroencefalografie*. Brno: Ústav pro další vzdělávání středních zdravotnických pracovníků, 1974.
- [3] Electroencephalography [online]. [2002 - 2012] [Citace: 24. 11. 2011]. Dostupné na [www: http://en.wikipedia.org/wiki/Electroencephalography](http://en.wikipedia.org/wiki/Electroencephalography)
- [4] Elektroencefalogram [online]. [2006 - 2012] [Citace: 24. 11. 2011]. Dostupné na [www: http://cs.wikipedia.org/wiki/Elektroencefalogram](http://cs.wikipedia.org/wiki/Elektroencefalogram)
- [5] MOHYLOVÁ, J. *Zpracování signálu v lékařství*. Elektronické skriptum. Žilina: Elektrotechnická fakulta, Žilinská univerzita, 2004.
- [6] JAN, J. *Číslicová filtrace, analýza a restaurace signálu*. Brno: Nakladatelství VUTIUM, 2002.
- [7] HORNIÁK, R. Diplomová práce: *Analýza EEG signálu*. Praha: ČVUT FEL, 2009.
- [8] KOLÁŘ, J. *BLDT_T5_EEG* (Přednáška předmětu Lékařská diagnostická technika). 2011. Dostupné na [www: http://www.vutbr.cz/elearning/file.php/111844/Prednasky/BLDT_T5_EEG.pdf](http://www.vutbr.cz/elearning/file.php/111844/Prednasky/BLDT_T5_EEG.pdf)
- [9] GAJDOŠ, M. Bakalářská práce: *Analýza elektroencefalografických signálů*. Brno: VUT, FEKT, 2010.
- [10] GERLA, V., KRAJČA, V., LHOTSKÁ, L., RIEGER, J. *Lékař a technika. Metody zpracování dlouhodobých EEG záznamů*. Praha: Česká lékařská společnost Jana Evangelisty Purkyně a ČVUT v Praze, 2008. Dostupné na [www: http://www.sbmili.cz/journal/LaT_2008_3.pdf](http://www.sbmili.cz/journal/LaT_2008_3.pdf)
- [11] NOVÁK, R., Diplomová práce: *Hodnocení EEG signálu v reálném čase*. Praha: ČVUT FEL, 2011.
- [12] Vlastnosti a modelování aditivního bílého šumu s normálním rozdělením [online]. [Citace: 15. 5. 2012] <http://noel.feld.cvut.cz/vyu/a2m99czs/pdf/awgn.pdf>
- [13] MathWorks. <http://www.mathworks.com/help/techdoc/ref/f16-6011.html>

Seznam použitých zkratek

EEG	elektroencefalogram
EKG	elektrokardiograf
CMR	potlačení soufázové složky
AAR	alfa atenuační reakce
RF	remund fenomén
JIP	jednotka intenzivní péče
FFT	rychlá Fourierova transformace (fast Fourier transform)
LP	lineární predikce

Přílohy

Zdrojový kód programu pro ověření algoritmu segmentace EEG signálu:

- Funkce pro načtení EEG signálů

```
function [eeg,time,Fvz,nastdelka]=read_eeg_fce(FileName)

data=fopen(FileName); %nacitani suboru

fseek(data,8,'bof');
Fvz=fread(data,1); %nacitani vzorkovaci frekvence

fseek(data,6144,'bof');
delka=fread(data,inf);
delka=(length(delka)/24)*(1/Fvz); %vypocitani delky zaznamu v s
nastdelka=delka; %nastaveni delky

fseek(data,184,'bof');
kanal=fread(data,1); %nacitani poctu ulozenych kanalu

fseek(data,182,'bof');
adresa=fread(data,1,'uint16'); %nacitani adresy 1. bytu pro 1. kanal

t=0:1/Fvz:nastdelka-1/Fvz;
eeg=zeros(kanal,length(t)); %vytvoreni nulove matice o velikosti,
jakou potrebujeme
for i=1:kanal
    fseek(data,(adresa+i)-1,'bof');
    vekt=fread(data,(Fvz*nastdelka),'uchar',23); %nacitani hodnot napeti
                                                    zvoleneho kanala
    eeg(i,:)=vekt'; %matice eeg: v kazdem
                                                    radku jeden kanal EEG
end

names={'GND','FP1','FP2','F3','F4','F7','F8','FZ','C3','C4','CZ','P3','P4',
'PZ','01','02','T3','T4','T5','T6','EOG','EMG','ECG','PNG'}';
time=t;
```

```

for j=1:kanal                                %rozkresleni kanalu
    eeg(j,:)=j*300+eeg(j,:);
end

figure(1)                                    %zobrazeni celeho EEG zaznamu
plot(time,eeg);
title('Analyzovaný EEG signál');
xlabel('Čas [s]');
ylabel('Amplituda');

end

```

- Zdrojový kód pro segmentaci na základě míry difference střední amplitudy a frekvence

```

clear all; close all; clc

cisloKanalů = 2;

[eeg,time,Fvz,nastdelka]=read_eeg_fce('pac02.trc');

for k = 1:24                                %zpet rozkreslení průběhu
    eeg(k,:) = eeg(k, :)-k*300;
end

WL = 60;                                     %nastavení délky okna
kA = 1;                                     %vahovací konstanty
kF = 7;
mez = 2800;                                %nastavení velikost meze

signal = eeg(cisloKanalů,:);

figure(2);
subplot(3,1,1);
plot(time,signal); %zobrazení vybraného kanálu eeg signálu

xlabel('Čas [s]');
ylabel('Amplituda');
title('Vybraný kanál EEG signálu');

for n = 1:(nastdelka*Fvz-2*WL-1)

    okno1=signal(n:n+WL);
    okno2=signal(n+WL+1:n+1+2*WL);

    Aw1(n) = sum(abs(okno1));                %vypočet amplitudy
    Aw2(n) = sum(abs(okno2));                jednotlivých oken

    for m = 2:WL-1
        Fw1(n) = sum(abs(okno1(m+1)-okno1(m-1)))); %vypočet frekvence
        Fw2(n) = sum(abs(okno2(m)-okno2(m-1))));   jednotlivých oken
    end
end

```

```

G(n) = kA*abs(Aw1(n)-Aw2(n))+kF*abs(Fw1(n)-Fw2(n)); %mira rozdilu oken

end

subplot(3,1,2);
plot(G); hold on; %vykresleni prubehu difference

xlim([1 800]);
title('Průběh difference');
ylabel('Míra difference');
xlabel('Vzorky signálu');

x=(0.00001:length(G));
plot(x,mez, 'r');

for o = 1:length(G) %vyber slozek, ktere prekracuji mez
    if G(o)>mez
        Q(o)=G(o);
    else Q(o)=0;
    end
end

P = find(Q>0); %pozice prvku nad mezi
S = diff(P);

H(1) = P(1);
pom = 2;

for a = 1:length(S)
    if S(a)>1
        H(pom) = P(a); %hranice mezi kterymi se hleda
        H(pom+1) = P(a+1); %lokalni maximum
        pom=pom+2;
    end
end

pom2=1;

for b = 1:2:length(H)-1

```



```

        [hodn poz] = max(G(H(b):H(b+1)));
        M(pom2) = poz+H(b);
        pom2 = pom2+1;
    end

    subplot(3,1,3);
    plot(signal); hold on;
    xlim([1 800]);

    stem(M,ones(1,length(M))*300, 'r');           %vykresleni hranic segmentu

    xlabel('Vzorky signálu');
    ylabel('Amplituda');
    title('Vybraný kanál EEG signálu s vyznačením segmentů');

```

- Zdrojový kód pro adaptivní segmentaci na základě míry difference odhadnuté z FFT

```
clear all; close all; clc

cisloKanalů2=2;

[eeg,time,Fvz,nastdelka]=read_eeg_fce('pac02.trc');

for k=1:24                                %zpet rozkreslení průběhu
    eeg(k,:)=eeg(k, :)-k*300;
end

WL = 60;                                % nastavení délky okna
mez2= 6*10^12;                          % nastavení velikost meze

signal=eeg(cisloKanalů2,:);

figure(2);
subplot(3,1,1);
plot(time,signal);

xlabel('Čas [s]');
ylabel('Amplituda');
title('Vybraný kanál EEG signálu');

for n = 1:(nastdelka*Fvz-2*WL-1)

    okno1=signal(n:n+WL-1);
    okno2=signal(n+WL+1:n+1+2*WL-1);

    m = linspace(0,WL-1, WL);

    for k = 1:WL/2

        Y1(k) = sum(okno1.*exp(-2*pi*1i*k*m/WL));
        Y2(k) = sum(okno2.*exp(-2*pi*1i*k*m/WL));

    end
end
```

```

Y1=abs(Y1);
Y2=abs(Y2);

G2(n) = max (0.5*(Y1./Y2+Y2./Y1)-1);

end

[pks2,locs2] = findpeaks(G2,'MINPEAKHEIGHT',mez2);

x = (0.00001:length(G2));

figure(2);
subplot(3,1,2);

plot(G2); hold on;
plot(x,mez2,'r');

xlim([1 800]);
title('Průběh difference');
xlabel('Vzorky signálu');
ylabel('Míra difference');

subplot(3,1,3);
plot(signal); hold on;
xlim([1 800]);

stem(locs2,ones(1,length(locs2))*300,'r')

ylabel('Amplituda');
xlabel('Vzorky signálu');
title('Vybraný kanál EEG signálu s vyznačením segmentů');

```